

Theorem

The greedy algorithm to compute a superstring is a 3-approximation algorithm for MCCSP.

Proof:

Greedy: $(S_{j_1}, S_{j_2}, \dots, S_{j_n})$

Optimum: $(S_{i_1}, S_{i_2}, \dots, S_{i_n})$

Wir zeigen: $\langle S_{j_k}, S_{j_{k+1}} \rangle$ kann höchstens drei Merges der optimalen Lösung unmöglich machen:

1. Fall: $\langle S_{j_k}, S_{j_{k+1}} \rangle = \langle S_{i_\ell}, S_{i_{\ell+1}} \rangle$ für $\ell \in [1:n-1]$

→ beide identisch, kein Merge verhindert

2. Fall: $\langle S_{j_k}, S_{j_{k+1}} \rangle = \langle S_{i_\ell}, S_{i_{\ell+m}} \rangle$, $m > 1$,

→ höchstens 2 Merges unmöglich, nämlich $\langle S_{i_\ell}, S_{i_{\ell+1}} \rangle$ und $\langle S_{i_{\ell+m-1}}, S_{i_{\ell+m}} \rangle$

$$\frac{S_{j_k}}{\overbrace{S_{i_\ell} \dots S_{i_{\ell+m}}}^{|l|}} S_{j_{k+1}}$$

$\langle S_{i_{\ell+m-1}}, S_{i_{\ell+m}} \rangle$

3. Fall: $\langle S_{j_k}, S_{j_{k+1}} \rangle = \langle S_{i_{\ell+m}}, S_{i_\ell} \rangle$ für geeignetes

→ höchstens 3 Merges unmöglich ℓ und $m > 0$

$\langle S_{i_{\text{curr}}}, S_{i_{\text{curr}+1}} \rangle$, $\langle S_{i_{\text{e}-1}}, S_{i_{\text{e}}} \rangle$ und einer der Merges $\langle S_{i_{\text{e}}}, S_{i_{\text{e}+1}} \rangle, \dots, \langle S_{i_{\text{e}+\text{m}-1}}, S_{i_{\text{e}+\text{m}}} \rangle$, da Anwendung zu Zykel führte

$$S_{i_1} \rightarrow S_{i_2} \rightarrow \dots \rightarrow S_{i_e} \rightarrow \dots \rightarrow S_{i_{e+m}} \rightarrow \dots \rightarrow S_{i_n}$$

↪ schließt Zykel \Rightarrow eine der Kanten \rightarrow unmöglich.

$M_x \hat{=} \text{Menge der Merges von Algorithmus } x \in \{g, o\}$

$V(m) \subseteq M_o \hat{=} \text{Menge der von } m = \langle S_{j_{k+1}}, S_{j_{k+1}} \rangle \in M_g$
verhinderten Merges

Für $ov(m)$, $m \in M_g$, Länge des durch m verschmolzenen Overlaps, gilt:

$$(\forall m \in M_g): (ov(m) \geq \frac{1}{3} \left(\sum_{m' \in V(m)} ov(m') \right)) \quad (*)$$

↑ max. 3 Summanden

dem Greedy wählt unter verbl. Merges immer den mit max. Overlap \rightarrow von m verhindelter Merge hat ov Overlap $> ov(m)$.

Außerdem gilt

$$(Hm' \in M_0) : (m' \in M_g) \vee ((\exists m \in M_g \setminus M_0) : (m' \in \bigvee(m)))$$

(xx)

denn für $m' = \langle S, \bar{S} \rangle \in M_g$ muß es in M_g Merges geben, die S und \bar{S} mit anderen Wörtern verschmelzen, wodurch m' verhindert wird. Ein solcher Merge kann nicht in M_0 liegen, da er ja $m' \in M_0$ verhindert.

Betrachte nun

$$\sum_{m \in M_g} \text{ov}(m) = \sum_{m \in M_g \cap M_0} \text{ov}(m) + \sum_{m \in M_g \setminus M_0} \text{ov}(m)$$

Es gilt:

$$\sum_{m \in M_g \cap M_0} \text{ov}(m) \geq \frac{1}{3} \sum_{m \in M_0 \cap M_g} \text{ov}(m) \quad \text{und}$$

$$\begin{aligned}
 \sum_{m \in M_g \setminus M_0} \text{ov}(m) &\stackrel{(*)}{\geq} \sum_{m \in M_g \setminus M_0} \frac{1}{3} \sum_{m' \in V(m)} \text{ov}(m') \\
 &\leq M_g \\
 &\stackrel{(**)}{\geq} \frac{1}{3} \sum_{m' \in M_0 \setminus M_g} \text{ov}(m') \\
 &\leq M_0 \\
 \implies \frac{\text{comp}(w_0)}{\text{comp}(w_3)} &= \frac{\sum_{m' \in M_0} \text{ov}(m')}{\sum_{m \in M_g} \text{ov}(m)} \leq \frac{\sum_{m' \in M_0} \text{ov}(m')}{\frac{1}{3} \sum_{m' \in M_0} \text{ov}(m')} = 3
 \end{aligned}$$

□

Using more elaborate reasoning one can show:

Theorem

The greedy algorithm to compute a superstring is a 2-approximation algorithm for MCCSP.

□

Alternative Procedure

Idea: Do not use a single cycle to cover all vertices but a set of cycles

→ cycle-cover for which each vertex must be part of exactly one cycle.

Here: Cycle-cover of minimal cost (according to distance graph).

Remark: A minimal cycle-cover can be computed in time $\mathcal{O}(n^3)$ (whereas the restriction to edges to be covered by at least one cycle leads to an \mathcal{NP} -complete problem).

Def.: Sei $G = (V, E, g)$ ein vollständiger Digraph mit Kantengewichten $g: E \rightarrow \mathbb{N}$. Ein Cycle-Cover von

G besteht aus einer Menge $\mathcal{K} = \{K_1, \dots, K_e\}$ gerichtete Kreise in G , so dass jeder Knoten in V in genau einem Kreis $K_i \in \mathcal{K}$ vorkommt.

Kosten: \sum Kantengewichte aller Kreise.

Approximation: Construct a single cycle (solution to TSP) from the minimal cycle-cover.

Steps:

1. Identify each cycle $c \in \mathcal{C}$ by one of its vertices \rightsquigarrow set of vertices R .
2. Compute a minimal cycle-cover for the subgraph induced by $R \rightsquigarrow$ set of cycles \mathcal{C}' .
3. For each $c \in \mathcal{C}'$ delete the edge corresponding to a merge of minimal overlap \rightsquigarrow broken cycles are considered as merged strings.
4. Concatenate these strings and expand each of its elements by the cycle from \mathcal{C} it represents.

$$K_1 = \textcircled{a_1} \rightarrow a_2 \rightarrow \dots \rightarrow a_n \rightarrow a_1 = \langle a_1, a_2, \dots, a_n \rangle$$

$$K_2 =$$

:

$$K_7 = \textcircled{g_1} \rightarrow g_2 \rightarrow g_3 \rightarrow g_1$$

$\textcircled{\quad}$ Repräsentant

r_{K_i}

alle zusammen = R

Cover for r_{K_i} :

$$K'_1 = a_1 \rightarrow b_1 \rightarrow c_1 \rightarrow a_1$$

$$K'_2 = d_1 \rightarrow e_1 \rightarrow d_1$$

$$U_3' = f_7 \not\rightarrow g_7 \rightarrow f_7$$

$$\left. \begin{array}{l} U_1 = \langle b_1, c_1, a_1 \rangle \\ U_2 = \langle e_1, d_1 \rangle \\ U_3 = \langle g_1, f_1 \rangle \end{array} \right\}$$

$$\leadsto w' = U_1 U_2 U_3$$

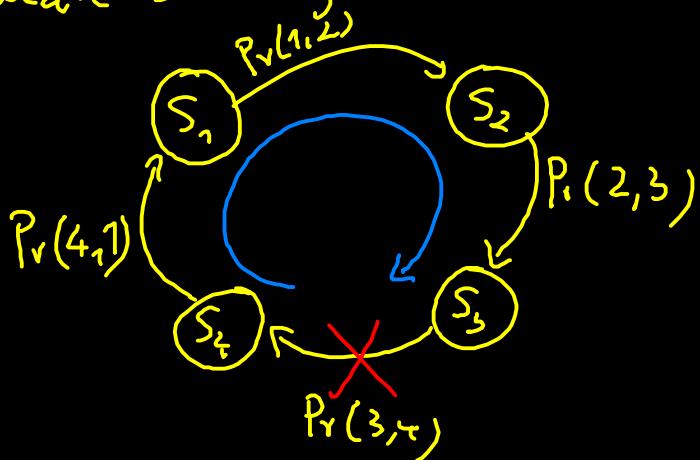
In w' ersetzen wir die Repräsentanten durch die zu ihm geh., „Kreise“

Theorem

The algorithm just outlined is a 3-approximation algorithm for SCSP.

Proof:

Optimale Lösung (TSP) sei



Kosten für SCSP

$$\begin{aligned} \text{Kosten TSP: } & Pr(1,2) + Pr(2,3) \longrightarrow Pr(4,1) + Pr(1,2) \\ & + Pr(2,3) + |S_3| \end{aligned}$$

Es gilt: $|S_i| > Pr(i,j) \Rightarrow$ Kosten TSP stets untere Schranke für SCSP. Außerdem sind Kosten

einer min. Cycle-Cover untere Schranke für Kosten
TSP

$$\Rightarrow \text{cost}(\mathcal{K}) = \text{Opt}_{cc}(DG(S)) \leq \text{Opt}_{SCS}(S)$$

$$\text{cost}(\mathcal{K}') = \text{Opt}_{cc}(DG(R)) \leq \text{Opt}_{SCS}(R)$$

Außerdem $\text{cost}(\mathcal{K}') \leq \text{cost}(\mathcal{K})$ (o)

$$|w_i| = \text{cost}(K'_i) + \text{minor}(K'_i)$$

↑ min. Overlap der Kreise K'_i

$$|w'| \leq \text{cost}(\mathcal{K}') + \sum_{K' \in \mathcal{K}'} \text{minor}(K') \quad (*)$$

Ersetzen wir in w' alle Repräsentanten durch „Kreis“

$$\rightsquigarrow Y_K = a_1 \rightsquigarrow \underbrace{P_1(1,2) \cdot P_1(2,3) \cdots P_1(4,1)}_{\mathcal{K}' \text{ verlängert sich um Gewicht}} \cdot a_1$$

w' verlängert sich um Gewicht ↑

$$|w| \leq |w'| + \text{cost}(\mathcal{K})$$

$$\stackrel{(*)}{\leq} \text{cost}(\mathcal{K}') + \sum_{K' \in \mathcal{K}'} \text{minor}(K') + \text{cost}(\mathcal{K})$$

$$\stackrel{(o)}{\leq} 2 \cdot \text{cost}(\mathcal{K}) + \sum_{K' \in \mathcal{K}'} \text{minor}(K')$$

Jeder Kreis mind.

Nur g'l. offensichtlich

$$\sum_{k' \in \mathcal{K}'} \text{minor}(k') \leq \frac{1}{2} \cdot \sum_{k' \in \mathcal{K}'} \sum_{(S_i, S_j) \in k'} \text{ov}(S_i, S_j)$$

$$\Rightarrow |w| \leq 2 \cdot \text{cost}(\mathcal{K}) + \frac{1}{2} \sum_{k' \in \mathcal{K}'} \sum_{(S_i, S_j) \in k'} \text{ov}(S_i, S_j)$$

Lemma: k_1, k_2 zwei Kreise in unv. $\mathcal{C} \subset \mathcal{K}$ und
 $w_1 \in k_1, w_2 \in k_2$ zwei Wörter in diesen Kreisen.

Dann gilt

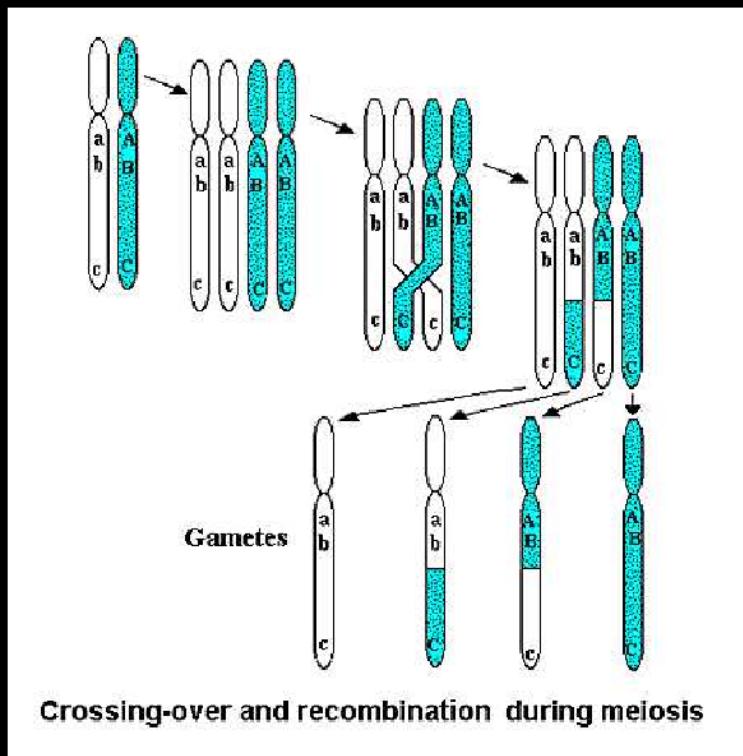
$$\text{ov}(w_1, w_2) \leq \text{cost}(k_1) + \text{cost}(k_2)$$

$$\Rightarrow \sum_{k' \in \mathcal{K}'} \sum_{(S_i, S_j) \in k'} \text{ov}(S_i, S_j) < \sum_{k' \in \mathcal{K}'} \sum_{(S_i, S_j) \in k'} (\text{cost}(k_i) + \text{cost}(k_j))$$

$$= 2 \cdot \text{cost}(\mathcal{K})$$

$$\Rightarrow |w| \leq 3 \cdot \text{cost}(\mathcal{K}) \\ \leq 3 \cdot \text{Opt}_{\text{SCS}}(S)$$

□



5' → 3'
 3' ← 5'

Crossing-over and recombination during meiosis